



**Universitat de les  
Illes Balears**

Facultat de Ciències

**Memòria del Treball de Fi de Grau**

# Verificación de modelos climáticos CMIP5: análisis de la estivalización de la primavera en el Mediterráneo Occidental

Daniel Rodríguez Tarry

**Grau de Física**

Any acadèmic 2016-17

DNI de l'alumne: 43171913Q

Treball tutelat per Víctor Homar Santaner  
Departament de Física

S'autoritza la Universitat a incloure aquest treball en el Repositori Institucional per a la seva consulta en accés obert i difusió en línia, amb finalitats exclusivament acadèmiques i d'investigació	Autor		Tutor	
	Sí	No	Sí	No
	x		x	

Paraules clau del treball:  
Mediterráneo; primavera, verano, CMIP5



## Contenidos:

<b>1. Introducción</b>	2
<b>2. Descripción del conjunto de datos</b>	5
<b>3. Método de análisis</b>	6
3.1. Análisis de componentes principales (PCA)	6
3.2. Rotación de los PCs	8
3.3. Evolución temporal de los PCs en más de un campo	9
<b>4. Resultados</b>	11
4.1. PCA: análisis de gran escala	11
4.1.1. Obtención de los PCs	11
4.1.2. Evolución temporal	12
4.2. PCA: análisis regional	15
<b>5. Discusión y conclusiones</b>	17
5.1. Fuentes de error	17
5.2. Comentarios finales sobre los resultados	18
5.3. Futuras líneas de trabajo	18
<i>Anexo I</i>	20
<i>Anexo II</i>	22
<i>Referencias</i>	23

## **1. Introducción**

---

Durante las últimas décadas se ha observado un calentamiento en el Mediterráneo Occidental, y en particular en las Islas Baleares muy superior al observado a escala global (0.43°C/década, enfrente de los 0.24°C/década promedio de nuestra latitud). El desequilibrio radiativo global producido por la intensificación del efecto invernadero no explicaría de manera directa un aumento tan importante. Debido a ello, se han barajado e investigado posibles mecanismos regionales responsables de tal aumento singular de las temperaturas.

Como se analiza en Trigo et al., (2006) el clima Mediterráneo se caracteriza por circulaciones tropicales y extratropicales. El verano Mediterráneo está dominado por una presencia anticiclónica de origen cálido y subtropical (Barry and Chorley 2010), consecuencia del desplazamiento septentrional de la zona de convergencia intertropical (ITCZ) y por tanto de la zona descendente de la célula de Hadley.

La célula de Hadley es un patrón de circulación climática cerrada vinculado a la convección tropical y que oscila entre el ecuador y latitudes de 30°. El principal forzamiento que rige esta circulación es la diferencia latitudinal de la radiación solar incidente. En términos generales y para un estado medio, el aire superficial intertropical se calienta e inestabiliza, elevándose por convección; en niveles medios-altos domina la divergencia hacia latitudes mayores. La circulación se cierra con la formación de subsidencias subtropicales (latitudes por encima de los 30°), que genera prominentes anticiclones de subsidencia y los vientos elíseos hacia el ecuador en niveles superficiales. Debido al efecto Coriolis, los elíseos se desvían hacia el Oeste en su camino hacia el ecuador. Por otra parte, la inclinación del eje de rotación de la tierra produce un desplazamiento del ecuador térmico a lo largo del año, provocando alteraciones en toda la circulación planetaria, incluida la oscilación latitudinal de la célula de Hadley. En el periodo de verano en el hemisferio norte, la célula de Hadley migra a latitudes más altas, provocando que su rama descendente sitúe el correspondiente anticiclón subtropical en las proximidades del Mediterráneo Occidental.

Uno de los indicadores de la expansión septentrional de la célula de Hadley son los campos de presión. En las primeras investigaciones se estudió el comportamiento de los campos de presión a nivel del mar, sin embargo, estos no dieron resultados consistentes (Hu et al., (2011)). Esto se debe a que las presiones a bajos niveles se ven muy influenciadas por la actividad anticiclónica y ciclónica de origen térmico, obteniendo así medias de presión observada a nivel del mar más altas en invierno que en verano. Por lo contrario, si nos fijamos en niveles medios atmosféricos, con menor influencia del calentamiento superficial, Jansà et al., (2012) identificó una gran correlación entre las tendencias de las temperaturas a 2 m con el aumento de la altura geopotencial a 500 hPa (H500, de aquí en adelante); posteriormente, Jansà et al., (2016) hizo un análisis más detallado de estos dos campos utilizando datos del reanálisis NCEP/NCAR. El estudio analiza las tendencias bimensuales en lugar del habitual análisis estacional trimestral, lo cual permite analizar independientemente los periodos plenamente estivales (Julio-Agosto) de los de transición (Mayo-Junio). Como resultado, Jansà et al., (2016) detectó que las tendencias del geopotencial a niveles medios en los bimeses de Marzo-Abril y Mayo-Junio era más del doble que en el resto del año, incluyendo al bimés propio del verano, Julio-Agosto, proporcionando una clara evidencia de la extensión o adelantamiento de las condiciones estivales hacia la primavera.

Respecto a las tendencias de la temperatura a 2m en el Aeropuerto de Palma de Mallorca, en el periodo comprendido entre 1973 y 2012, se observa un calentamiento en todos los bimeses, siendo Mayo-Junio el bimes con mayor correlación de la tendencia de la temperatura a 2m con la tendencia del H500. Como consecuencia, se decidió tomar el periodo correspondiente a los meses de Mayo y Junio como indicador de la expansión o adelantamiento de las condiciones estivales a la primavera.

Otro resultado obtenido de este análisis fue la determinación de la zona afectada por este aumento de la altura geopotencial. En la *Figura 1.1(a)* se puede ver como las tendencias positivas más intensas se encuentran sobre todo el Mediterráneo Occidental, confirmando que no se trata de un fenómeno local sino de escala regional.

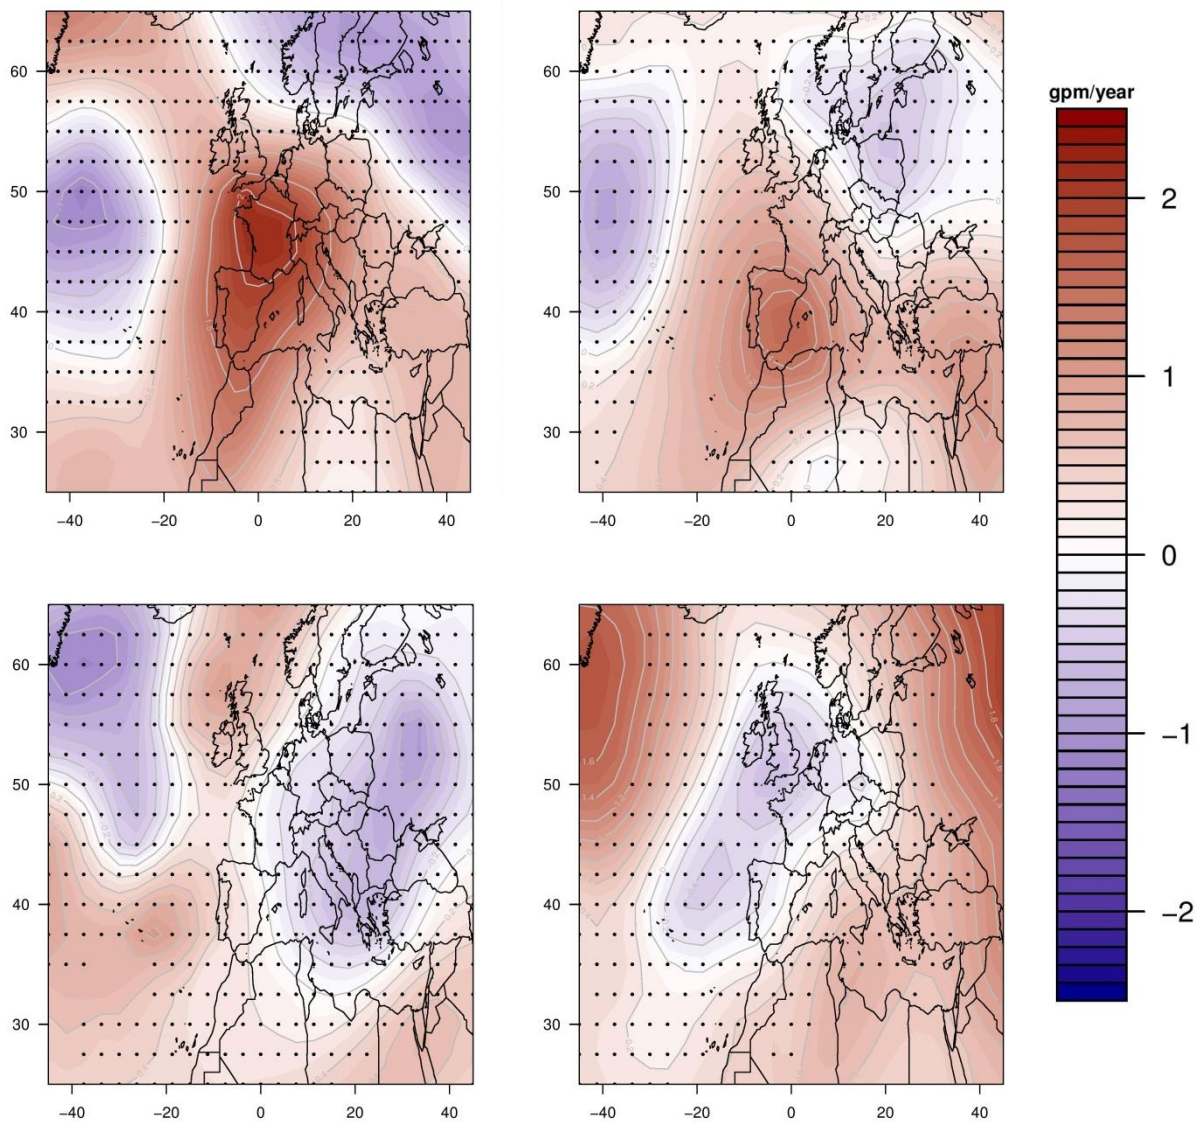
Todos estos resultados indicarían un cambio regional más importante del observado a escala global de la expansión de la célula de Hadley y la ITCZ hacia el norte (Hu y Fu (2007), IPCC, (2013); Birner et al., (2014)).

Tomando estos resultados como punto de partida, se definió el objetivo del presente trabajo. Con el objetivo inicial de analizar las proyecciones futuras que describen los modelos actuales de predicción del clima con respecto a la estivalización de la primavera en el Mediterráneo Occidental se abordó una verificación simple con el fin de confirmar la capacidad de los modelos del CMIP5 de reproducir el fenómeno observado por Jansà et al., (2016). Esta verificación se realizó calculando la correlación espacial de los campos de tendencias *observado*<sup>1</sup> y simulado por cada modelo CMIP5 considerado. Un primer resultado interesante tras este cálculo es que ningún modelo muestra capacidad de simular el fenómeno, y por consiguiente no parece poder ser usado con carácter predictivo. En la *Tabla 1.1* se muestran las correlaciones entre las tendencias calculadas a partir de los modelos climáticos utilizados y el reanálisis NCEP/NCAR para el dominio de estudio (detallado en la siguiente sección). Los valores de correlación obtenidos dejan poco margen a la duda, con un único valor de los 20 explorados por encima de 0.6 y numerosos modelos simulando tendencias del H500 con patrones anticorrelacionados con los observados.

MODELO	Correl.	MODELO	Correl.
EC-EARTH_r2i1p1	0,024	HadCM3_r9i1p1	-0,386
EC-EARTH_r9i1p1	0,040	HadCM3_r10 i1p1	0,250
HadCM3_r1i1p1	-0,382	HadGEM2-ES_r2i1p1	0,512
HadCM3_r2i1p1	0,723	HadGEM2-ES_r3i1p1	0,223
HadCM3_r3i1p1	-0,163	HadGEM2-ES_r5i1p1	-0,409
HadCM3_r4i1p1	0,006	MRI-CGCM3_r1i1p1	0,510
HadCM3_r5i1p1	0,549	MRI-CGCM3_r2i1p1	-0,335
HadCM3_r6i1p1	-0,487	MRI-CGCM3_r3i1p1	-0,282
HadCM3_r7i1p1	0,396	MRI-CGCM3_r4i1p2	-0,142
HadCM3_r8i1p1	-0,122	MRI-CGCM3_r5i1p2	0,384

*Tabla 1.1* Correlaciones espaciales entre las tendencias calculadas por los modelos climáticos y el reanálisis del NCEP/ NCAR.

<sup>1</sup> Nos referimos en el texto al reanálisis NCEP/NCAR como observaciones al ser la mejor representación sobre malla del estado atmosférico.



*Figura 1.1* Tendencias bimensuales de Mayo-Junio de H500 para: (a)Superior izquierda, NCEP/NCAR; (b)Superior derecha, HadCM3\_r2 (corr: 0,723); (c)Inferior izquierda, HAdCM3\_r4 (corr: 0,006); (d)Inferior derecha, HadCM3\_r6 (corr: -0,487). Los puntos indican tendencias no significativas estadísticamente al 95%.

Para dar ilustrar lo que representan estas correlaciones, en la *Figura 1.1* se muestran el campo de tendencias calculado a partir del reanálisis NCEP/NCAR, y de 3 simulaciones distintas del HadCM3. El hecho de que no solo no obtengamos correlaciones altas entre modelos y observaciones, sino que además las correlaciones entre simulaciones igual de probables de un mismo modelo sean tan diferentes hace indicar que las tendencias bimensuales de geopotencial no son un fenómeno predecible por estos modelos, lo cual pondría de relieve una carencia importante de estos modelos imprescindibles para el estudio del clima futuro.

A raíz de estos resultados, se plantea un objetivo alternativo en el trabajo, enfocado a analizar las causas que explican tal carencia general en los modelos CMIP5. El estado atmosférico se estudia con frecuencia en base a patrones que persistentemente se repiten a lo

largo del tiempo. De esta manera, un campo atmosférico como el geopotencial a 500 hPa puede descomponerse en patrones generales que se repiten con mayor o menor intensidad a lo largo del tiempo. El objetivo particular de este trabajo es el análisis de la predictibilidad de las tendencias del H500 basado en el estudio de la predictibilidad de la evolución de la frecuencia de los patrones principales que definen el clima en la región.

Con este objetivo se propuso realizar un análisis de componentes principales (PCA) del H500, para después estudiar su evolución temporal y evaluar la capacidad de los modelos climáticos de simular los cambios en las frecuencias de cada modo de variabilidad individualmente. Este análisis contribuirá a la comprensión de las causas que explican las carencias descritas en los modelos climáticos.

## 2. Descripción del conjunto de datos

El conjunto de datos que hemos utilizado en la elaboración de este trabajo puede agruparse en 21 bases de datos:

### Reanálisis NCEP/NCAR + 4 modelos climáticos

El reanálisis NCEP/NCAR es un conjunto de datos proporcionado por *National Centers for Environmental Prediction* (NCEP) y *National Center for Atmospheric Research* (NCAR) que combina observaciones con predicciones, y que describe el estado de la atmosfera, manteniendo los datos actualizados y homogéneos desde el 1948 hasta el presente.

Los modelos climáticos utilizados pertenecen al proyecto CMIP5 (Coupled Model Intercomparison Project phase 5), los cuales combinan componentes atmosféricas y oceánicas. Como hemos podido ver en la Tabla 1.1, para un mismo modelo hay diferentes simulaciones, éstas se etiquetan con un *Ensemble number: r<N>i<M>p<L>* (*realization, initialization method, physics version*), Taylor (2012). Esta triada de números enteros (N, M, L) diferencia las simulaciones de un mismo modelo. El primer número, N, representa el número de veces que se ha hecho correr el modelo, cada cual con condiciones iniciales diferentes pero todas igual de realistas, como por ejemplo cambiar la fecha en la que se inicializa. El segundo número, M, representa el método de iniciación del modelo, es decir, según como han sido inicializadas las condiciones iniciales o qué conjunto de datos se ha utilizado. Por último, el tercer número, L, representa los parámetros físicos presentes en el modelo como por ejemplo diferentes tipos de forzamiento. Por tanto, la diferencia entre los modelos “HadCM3\_r1i1p1” y “HadCM3\_r2i1p1”, es que se hicieron correr en fechas distintas o con condiciones iniciales diferentes. Por otra parte, la diferencia entre los modelos “MRI-CGCM3\_r3i1p1” y “MRI-CGCM3\_r4i1p2” es que aparte de tener condiciones iniciales diferentes también tienen parametrizaciones físicas diferentes.

NCEP/NCAR	EC-EARTH (Europa)	HadCM3 (UK)	HadGEM2_ES (UK)	MRI-CGCM3 (Japón)
lon: 2.5°	lon: 1.125°	lon: 3.75°	lon: 1.875°	lon: 1.125°
lat: 2.5°	lat: 1.125°	lat: 2.5°	lat: 1.125°	lat: 1.125°

Tabla 2.1 Resolución de la malla espacial de los modelos climáticos analizados

A la hora de comparar resultados y hacer cálculos con diferentes modelos tenemos que tener en cuenta que cada modelo posee su propia malla de resolución espacial (*Tabla 2.1*)<sup>2</sup>. Por tanto, para poder hacer cálculos utilizando datos de diferentes modelos habrá que hacer una interpolación de todos los datos a una malla común que por formalismo será la malla del NCEP.

De todos estos modelos teníamos los campos medios mensuales de altura geopotencial, para todas las latitudes y longitudes a diferentes alturas. A la hora de hacer nuestro análisis, lo primero que tuvimos que hacer fue delimitar un dominio el cual, para comparar resultados, se decidió que fuese el mismo que el utilizado en Jansà et al., (2016):

- Espacial: Longitudinal: [-45°, 45°], latitudinal: [25°, 65°]
- Temporal: De Enero de 1971 a Diciembre de 2005 (35 años)<sup>3</sup>

### 3. Método de análisis

---

#### 3.1. Análisis de Componentes Principales (PCA)

En esta sección se explicará el fundamento teórico sobre el análisis de componentes principales (PCA), el cual se puede encontrar en Jolliffe, (2002) y Wilks, (2006), y su aplicación a nuestro conjunto de datos.

El PCA es una de las técnicas más usadas a la hora de manipular grandes cantidades de datos ya que como resultado obtenemos un nuevo conjunto de datos formado por combinaciones lineales del conjunto original y de dimensiones más reducidas. Estas combinaciones lineales están elegidas de tal forma que contengan la mayor variabilidad posible descrita por el conjunto de datos inicial. Por tanto, el PCA resulta en una forma mucho más compacta de representar la variación de un sistema. En el caso de datos atmosféricos y, otro tipo de datos geofísicos, se utiliza para estudiar tanto la variabilidad temporal como la espacial.

Por tanto, el esquema general del PCA sería,

$$\mathbf{x}(K) \xrightarrow{PCA} \mathbf{u}(M) \quad (1)$$

donde  $\mathbf{x}$  representa el conjunto de datos inicial y  $\mathbf{u}$  representa el nuevo conjunto de datos cuyas componentes son combinaciones lineales de  $\mathbf{x}$ . La primera componente del vector  $\mathbf{u}$  ( $u_1$ ), o la primera Componente Principal (PC), es la combinación lineal de  $\mathbf{x}$  que representa la mayor varianza del sistema entre todas las otras combinaciones lineales. El resto de PC,  $u_2, u_3, \dots$ , serán las siguientes combinaciones lineales ordenadas de mayor a menor varianza representada. Todas ellas sujetas a la condición de que no tienen que estar correlacionadas, es decir, tienen que formar una base ortogonal. Por tanto, el segundo PC representa la mayor varianza del

---

<sup>2</sup> Para que el lector se haga una idea de la resolución de la malla, en latitudes medias un grado en latitud corresponde ~111 km y en longitud a ~80 km.

<sup>3</sup> Jansà et al., (2016) hizo un análisis de 40 años (1971-2010), pero en el momento que se comenzó este estudio los modelos climáticos solo poseían datos hasta 2005. Aunque implicaba tener un muestreo menor, se decidió no mantener la cantidad de 40 años, lo cual hubiese supuesto avanzar el análisis a 1966 incorporando nuevos datos haciendo inviable la comparación, por lo cual se optó por reducir el dominio temporal a cambio de conservar la viabilidad de la comparación.



sistema una vez hemos eliminado la varianza representada por el primer PC y además tiene que ser ortogonal a éste; el tercero seguirá el mismo razonamiento y tendrá que ser ortogonal al primer y segundo PC. Así sucesivamente hasta obtener las  $M$  componentes principales.

Estos PCs vienen definidos por los autovectores de la matriz de covarianza de  $\mathbf{x}$ , el  $m$ -ésimo PC ( $u_m$ ) se puede obtener a partir de proyectar nuestra matriz de datos  $\mathbf{x}^T$  sobre el  $m$ -ésimo autovector  $e_m$  (2).

$$u_m = e_m^T \mathbf{x} = \sum_{k=1}^M e_{km} x_k, \quad m = 1, \dots, M \quad (2)$$

Estos autovectores están ordenados geoméricamente representando las direcciones de mayor a menor variabilidad. De esta forma, el primer autovector ( $e_1$ ) está asociado al autovalor más grande ( $\lambda_1$ ), donde cada autovalor indica la varianza representada por su respectivo PC. Los autovectores forman un nuevo sistema de coordenadas en el que poder representar los datos donde cada PC reproduce una parte de la varianza total del sistema.

En la expresión (3) podemos ver la relación entre un campo original  $\phi_{xy}$  y su representación en la base de PCs. En este caso, se puede observar que no estamos haciendo el desarrollo del campo original, sino de su versión normalizada. Por una parte le sustraemos la media para así quedarnos con las anomalías. Es un tratamiento común en el PCA debido a que de esta forma podemos comparar PCs de campos con distintas magnitudes (por ejemplo, campos de altura geopotencial a diferentes niveles de altura). Por otra parte, dividimos por la desviación estándar para su normalización. Como resultado, obtenemos un desarrollo en tantos sumandos como PCs tengamos. Los coeficientes  $PC_i$  (o *loadings*) representan las componentes de los PCs en la base original, mientras que los coeficientes  $\gamma_1$  (o *scores*) representan la contribución de estos al campo original.

$$\frac{\phi_{xy} - \overline{\phi_{xy}}}{sdev(\phi_{xy})} = \gamma_1 PC_1 + \gamma_2 PC_2 + \dots + \gamma_M PC_M. \quad (3)$$

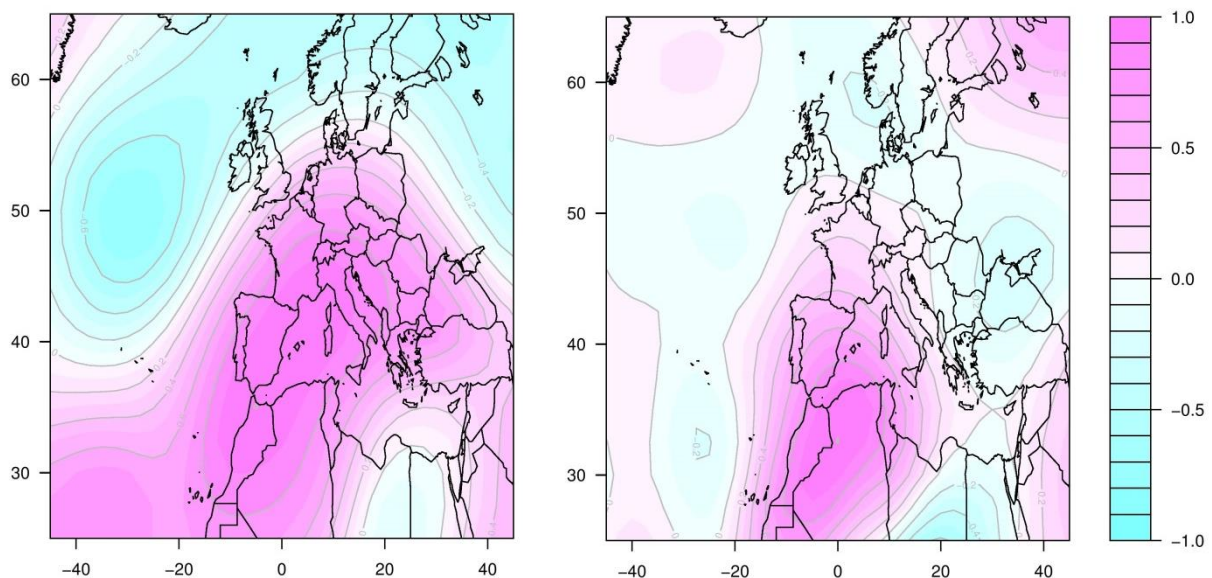
Como ya hemos comentado, cada PC reproduce una parte de la varianza total del campo y por consiguiente, la varianza total representada por los PC se hallará cuando consideremos el conjunto completo de todos ellos. Debido a esto, se puede reconstruir el campo original a partir de los PC y sus *scores*, cuantos más PC consideremos más próxima será nuestra reconstrucción al campo original. Otra apreciación importante respecto a la varianza representada es que la mayor parte de ésta estará representada por los primeros PCs. Matemáticamente hay tantos PCs como dimensiones tiene  $\mathbf{x}$ , esto es  $M = K$ , pero muchos de estos PCs apenas describirán la varianza del sistema debido a que la mayor parte de ésta se halla en los primeros PCs y los últimos solamente representan direcciones de variaciones muy pequeñas e irrelevantes para el objetivo del presente análisis. Es aquí donde aparece una de las principales ventajas del PCA, la reducción del volumen de datos. Podemos reducir el tamaño del conjunto de datos con el que estamos trabajando a cambio de renunciar a una parte irrelevante de la variabilidad del sistema. Con este procedimiento, a cuanto más variabilidad renunciemos, más reduciremos nuestro conjunto de datos. No existe un claro criterio a la hora de elegir el número de PCs que mantener. La elección del nivel de truncación puede ser tomada basándose en reglas de selección de PCs disponibles, pero en última instancia no dejará de ser una elección subjetiva que dependerá, en parte, de los datos y el propósito del PCA. En este trabajo se utilizará el criterio basado en la

varianza acumulada por los PCs, indicando el nivel de truncación de PCs según se llegué a una varianza acumulada determinada. En este estudio, truncaremos nuestra base de PCs una vez se haya alcanzado el 95% de la variabilidad del sistema original.

### 3.2. Rotación de los PCs

A la hora de analizar los PCs, sobretodo en análisis físicos, es común rotar la base de PCs debido a las ventajas que presenta. En Richman, (1986), se discute una serie de problemas que se presentan a la hora de analizar PCs no rotados y que, después de rotarlos, se observan en menor cantidad o intensidad. Uno de estos problemas es la dependencia de los PCs con el dominio escogido. En este caso se observa como los PCs resultantes dependen más del dominio escogido que no de la covarianza de los datos. Otra manifestación de esta dependencia surge si dividimos el dominio de análisis y realizamos el PCA de estos dos subdominios, obtendremos unos PCs totalmente distintos a los del dominio principal. Uno de los objetivos principales del PCA es la descomposición de variables en modos invariantes de variabilidad, objetivo que los PCs no rotados no satisfacen, sin embargo, los PCs rotados se ven menos afectados por la selección de dominio. Otra desventaja de las soluciones no rotadas se produce cuando el análisis tiene valores propios estrechamente espaciados. North et al., (1982) muestra que los errores de muestreo se hacen muy grandes si los valores propios vecinos son muy cercanos causando que los patrones de los PCs puedan mezclarse. Además los PCs rotados representan mejor los modos de variación físicos.

La mayoría de los métodos de rotación buscan simplificar la interpretación de los PCs mediante la creación de estructuras simples (polarización de los PCs). La polarización de los PCs se consigue haciendo tender los *loadings* hacia cero o hacia su valor absoluto máximo (que debido al escalado utilizado suele ser uno). La idea de este proceso es mostrar qué variables son más importantes que otras y así facilitar la interpretación de los PCs. En la *Figura 3.1* podemos examinar la diferencia entre considerar PCs no rotados (*Figura 3.1(a)*) o PCs rotados (*Figura 3.1(b)*). En este ejemplo podemos observar claramente el efecto “polarizador” de la



*Figura 3.1* En la izquierda (a) representación de un PC no rotado; en la derecha (b) representación de un PC rotado.

rotación, ya que pasamos de tener dos modos de variabilidad de grandes extensiones en un mismo PC a tener uno solamente y bien definido en una zona, en otras palabras, una estructura más simple.

Sin embargo, rotar también aporta desventajas y pérdida de información. Una es la pérdida de la propiedad de la varianza dominante, dicho de otra forma, el primer PC ya no es aquél que representa la mayor varianza del sistema. Esto se debe a que cuando hacemos una rotación de nuestra base de PCs, la varianza total representada por estos se mantiene pero sin embargo se redistribuye entre todos ellos, provocando que el espectro de autovalores sea más uniforme. A consecuencia de esto, la elección de con cuantos PCs nos quedemos tras la truncación adquiere una gran importancia. Según la cantidad de PCs que tengamos tras la truncación la varianza total del sistema se repartirá de una forma u otra.

También cabe tener en cuenta que existe una gran variedad de métodos de rotación, aunque comúnmente el más usado (y el que nosotros usaremos aquí) es el método de rotación *varimax*. Este método busca una rotación (combinación lineal) de los PCs originales tal que la varianza de los *loadings* sea máxima, lo que equivale a maximizar la expresión

$$\sum_{m=1}^M \left[ \sum_{k=1}^K e_{k,m}^{*4} - \frac{1}{K} \left( \sum_{k=1}^K e_{k,m}^{*2} \right)^2 \right], \quad (4)$$

donde

$$e_{k,m}^* = \frac{\tilde{e}_{k,m}}{\left( \sum_{m=1}^M \tilde{e}_{k,m}^2 \right)^{1/2}}, \quad (5)$$

son la versión escalada de los elementos de los autovectores rotados.

### 3.3. Evolución temporal de los PCs en más de un campo

El objetivo de este trabajo es el análisis de los PCs de los campos de diferentes modelos y observaciones con el objetivo de hallar porqué los primeros no son capaces de reproducir las tendencias observadas. Si hiciésemos un análisis independiente de componentes principales para cada conjunto de datos, tendríamos tantas bases de PCs como conjuntos de datos tuviésemos, haciendo que la comparación entre PCs de modelos fuese larga, tediosa y difícil de cuantificar. Sin embargo, una forma más conveniente de realizar este tipo de análisis consiste en establecer una base de PCs como la base principal y después analizar esta base en los diferentes campos. Realizando este procedimiento mantenemos los *loadings* constantes para todos los campos y lo que obtenemos como resultado son sus *scores*, de esta forma vemos como varían los *scores* (recordamos que los *scores* son las componentes de un campo en la nueva base, o lo que cada PC contribuye al campo original) según el campo que estemos estudiando.

Como consecuencia, el estudio de la evolución temporal de los *scores* indicará como varía cada modo de variabilidad en ese campo. El primer orden de variación se puede obtener mediante un ajuste lineal por mínimos cuadrados tipo  $y = a + b \cdot t$  de la serie temporal de *scores*. En este caso, el resultado del ajuste que nos interesará será el parámetro  $b$ , el cual vendrá dado juntamente con una probabilidad de significancia estadística. Esta probabilidad indica la confianza estadística de que haya una pendiente o no en el ajuste, tomando como umbral mínimo de significancia estadística 0,95. Esto se debe a que estamos considerando que los puntos de la serie temporal corresponden a muestras de variables aleatorias que siguen una distribución de probabilidad (Figura 3.2). Esta incertidumbre esta originada debido a la posible aleatoriedad en la obtención de los valores y su efecto en estos, en la mayoría de variables naturales esta incertidumbre viene descrita por una distribución de probabilidad gaussiana. Dicho con otras palabras, la distribución de probabilidad gaussiana de un dato representa las probabilidades del valor real de la magnitud dada una realización dada.

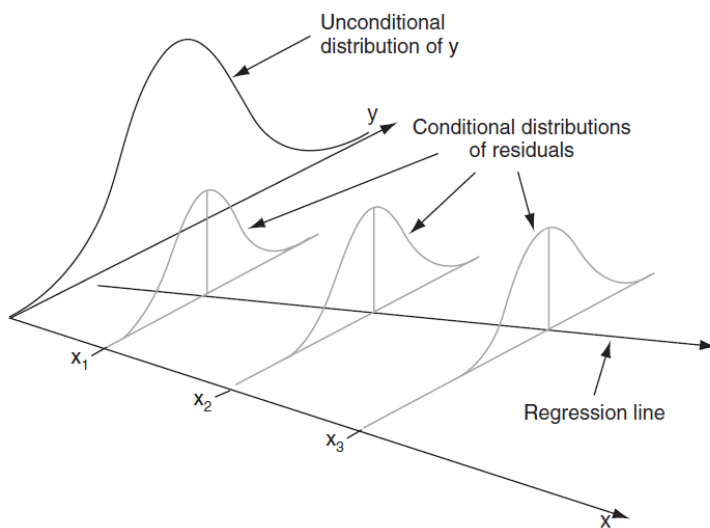


Figura 3.2 Esquema de la distribución probabilística de los datos y de su efecto en el ajuste lineal. Imagen obtenida de Wilks (2006), Figura 6.2.

En este trabajo consideraremos que la distribución de probabilidad es la misma para toda la serie de datos, la cual está calculada a partir de la variación de la propia serie temporal. En consecuencia, la pendiente resultado del ajuste también seguirá una distribución de probabilidad. Tener una significancia estadística implica que el 95% del área de esta distribución de probabilidad no incluye el valor de pendiente nula ( $b=0$ ). Casos en los que hay pocos datos con los que realizar el ajuste o que poseen tendencias muy leves serán propensos a obtener significancias estadísticas por debajo del 95% debido a la dificultad de determinar si hay una pendiente real o no.

Finalmente, una vez obtenidos los coeficientes  $b$  para todos los PCs de todos los campos, podremos comparar las evoluciones temporales de los modos de variabilidad modelos y observaciones y analizar qué modos están bien descritos y cuáles no.


## 4. Resultados

### 4.1. PCA: análisis de gran escala

#### 4.1.1. Obtención de los PCs

Como se ha comentado en la sección anterior, para facilitar el análisis de los PCs de todo nuestro conjunto de datos, hay que establecer un campo como base principal que haga de referencia para los demás. En este trabajo estamos comparando las tendencias de los modelos con el reanálisis NCEP/NCAR, de modo que por coherencia, se establecerá este campo como la base de PCs y se analizará como son descritos sus modos de variabilidad en los modelos climáticos.

Los resultados de realizar el PCA sobre el reanálisis NCEP/NCAR se muestran en la *Figura 4.1*. Lo primero que se puede apreciar es la distribución de varianza entre los PCs, donde cada PC está ordenado según la variabilidad de los datos originales que explica. Como resultado del PCA se obtiene un total 35 PCs debido a que, matemáticamente, se obtienen tantos PCs como el mínimo de la dimensión espacial y temporal del problema. En este trabajo, el PCA se está realizando sobre la dimensión espacial, aunque el número de años es 35, obteniendo así 35 PCs. Como se ha comentado, la mayor parte de la varianza del sistema está descrita por los primeros PCs, permitiendo reducir el volumen de datos truncando la base de PCs. Acorde con el criterio de truncación que se expuso en el capítulo anterior (truncar la base de PCs cuando se llegase a una varianza explicada acumulada del 95% de la varianza de los datos originales), truncaremos la

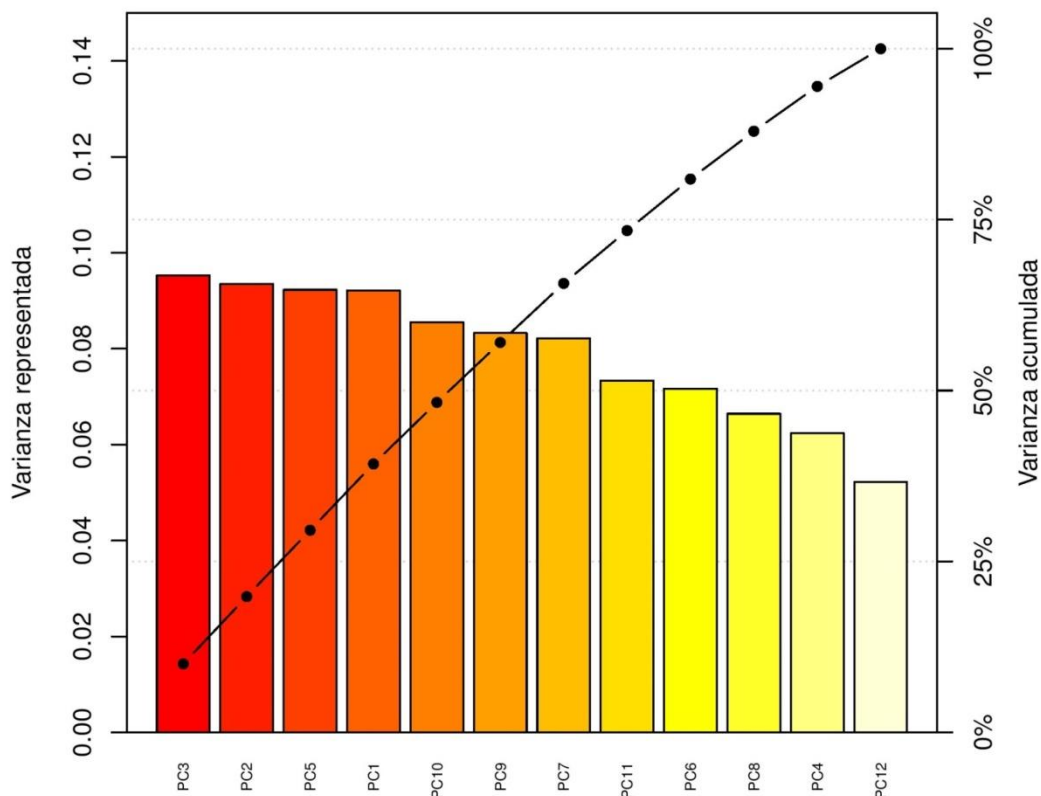


*Figura 4.1* Varianza representada por la base de PCs no rotada. Varianza representada por cada PC (barras), varianza acumulada (línea punteada), umbral del 95% de la varianza total acumulada (línea azul)

base de PCs a partir del PC 12. Esto supone una reducción del 65% del volumen de datos a cambio de renunciar solamente a un 5% de la variabilidad del sistema.

Una vez truncada la base de PCs podemos proceder con la rotación de ésta. Los resultados de aplicar una rotación *varimax* a la base de PCs se muestran en la *Figura 4.2*. Se puede observar como la varianza total conservada (que ahora es el 95% de la varianza total del sistema) está distribuida de forma más uniforme de lo que estaba en el espectro de PCs no rotados, en consecuencia, ya no existe un PC dominante respecto al resto en nuestro dominio.

La representación física de estos 12 modos principales de variabilidad (normalizados) se halla en el Anexo I. Fijándose en los mapas allí presentes puede apreciarse como uno de los objetivos que se perseguía con la rotación de los PCs ha sido alcanzado, la representación de un único modo de variabilidad por PC. En estas figuras se puede apreciar el efecto polarizador de la rotación, los modos de variabilidad de cada PC están representados por unas pocas variables, es decir, no hay dos modos de variabilidad que estén ubicados en la misma zona; y un grupo de variables está relacionado solamente con un PC, alcanzando así una *estructura simple* en cada PC. El estudio de las evoluciones temporales de los *scores* de cada PC indicará cómo evolucionan éstos y en consecuencia los campos de altura geopotencial. Para la correcta determinación de la evolución, y en qué sentido se produce, hay que analizar la tendencia de los *scores* juntamente con sus PCs. Una tendencia negativa de un *score* no implica un descenso de la altura geopotencial de nuestro campo ya que depende del signo del PC al que corresponde, si éste es negativo, por ejemplo, tendremos que un modo de variabilidad negativa cada vez contribuye menos al campo total y por tanto haciendo que, a falta del estudio del resto de PCs, el campo tenga una altura geopotencial superior.




*Figura 4.2* Varianza representada por la base de PCs rotada. Varianza representada por cada PC (barras), varianza acumulada (línea punteada).

#### 4.1.2. Evolución temporal

Una vez obtenida la base de PCs de referencia podemos proceder con el cálculo de los *scores* de los modelos climáticos sobre esta base para, a continuación, estudiar su evolución temporal.

A pesar de que los *scores* indican cuanto contribuye cada PC al campo total instantáneo bimensual, analizar estos resultados con detalle temporal y para cada modelo daría para hacer un propio trabajo sobre ello, ya que debido a la magnitud del volumen de datos (20 modelos  $\times$  12PCs  $\times$  35 años, 8400 resultados) requeriría de una gran cantidad de tiempo además de que sería difícil llegar a una conclusión clara. En su lugar, se calcularán las evoluciones temporales de los *scores*, dejándonos un conjunto de datos más viable de cara a un análisis físico de los resultados.

En la *Figura 4.3* están representadas las series temporales de los *scores* para los dos primeros PCs de todos los modelos y el NCEP/NCAR. Observando estos gráficos se puede anticipar que debido a la gran variabilidad de los *scores* en comparación con su tendencia y la longitud de la serie, habrá muchos cálculos de tendencia no significativos estadísticamente. Los resultados de hacer el ajuste por mínimos cuadrados a cada una de estas series temporales para todos los PCs se muestran la *Tabla II.1* del Anexo II.



*Figura 4.3* Representación de las series temporales de los *scores* del reanálisis NCEP/NCAR (negro) y modelos CMIP5 (gris) del PC1 y PC2.

Observando la *Tabla II.1* lo primero que encontramos son los resultados para el reanálisis NCEP/NCAR. En 5 de los 12 PCs obtenemos tendencias significativas estadísticamente con una clara intensidad (PC1, PC5, PC6, PC8 y PC10). Excepto en el PC1, el resto de *scores* poseen una tendencia negativa; sin embargo, si examinamos los signos de los modos de variabilidad presentes en estos PCs, salvo el PC1 representa un modo de variabilidad positivo, el resto son modos negativos. Por tanto, el H500 del reanálisis NCEP/NCAR tiene un modo de variabilidad positivo que cada vez contribuye más al campo total y 4 modos de variabilidad negativos que cada vez contribuyen menos al campo total. Como resultado, el H500 tendrá una clara tendencia positiva. Este análisis no nos da un resultado nuevo, ya que se conocían de antemano las

tendencias del NCEP/NCAR (Figura 1.1(a)). Sin embargo, proporciona información adicional sobre las causas y la atribución a modos climáticos específicos de estas tendencias. El análisis de tendencias mediante PCs permite conocer qué modos de variabilidad son los que están provocando dicha tendencia permitiendo, mediante el estudio de los mecanismos físicos que hay detrás de cada modo, averiguar cuáles son las causas de las tendencias en los campos de altura geopotencial.

La Figura 4.4 muestra el conjunto completo de PCs rotados del NCEP/NCAR juntamente con las intensidades de las tendencias de cada PC. Se muestran únicamente los PCs con valor de tendencia superior a 0.5 (ó -0.5 en caso de que el modo de variabilidad sea negativo) limitando así la principal zona de variabilidad de cada PC. En esta representación se aprecia con claridad los resultados de la rotación (explicados anteriormente), especialmente el hecho de que no haya más de un modo de variabilidad definido sobre la misma región. Los signos representados sobre cada modo de variabilidad, indicadores de su tendencia, están clasificados de la forma: "--", "-", "=", "+", "+" y "+"; donde "--" indica una fuerte tendencia negativa y "+" una fuerte tendencia positiva.

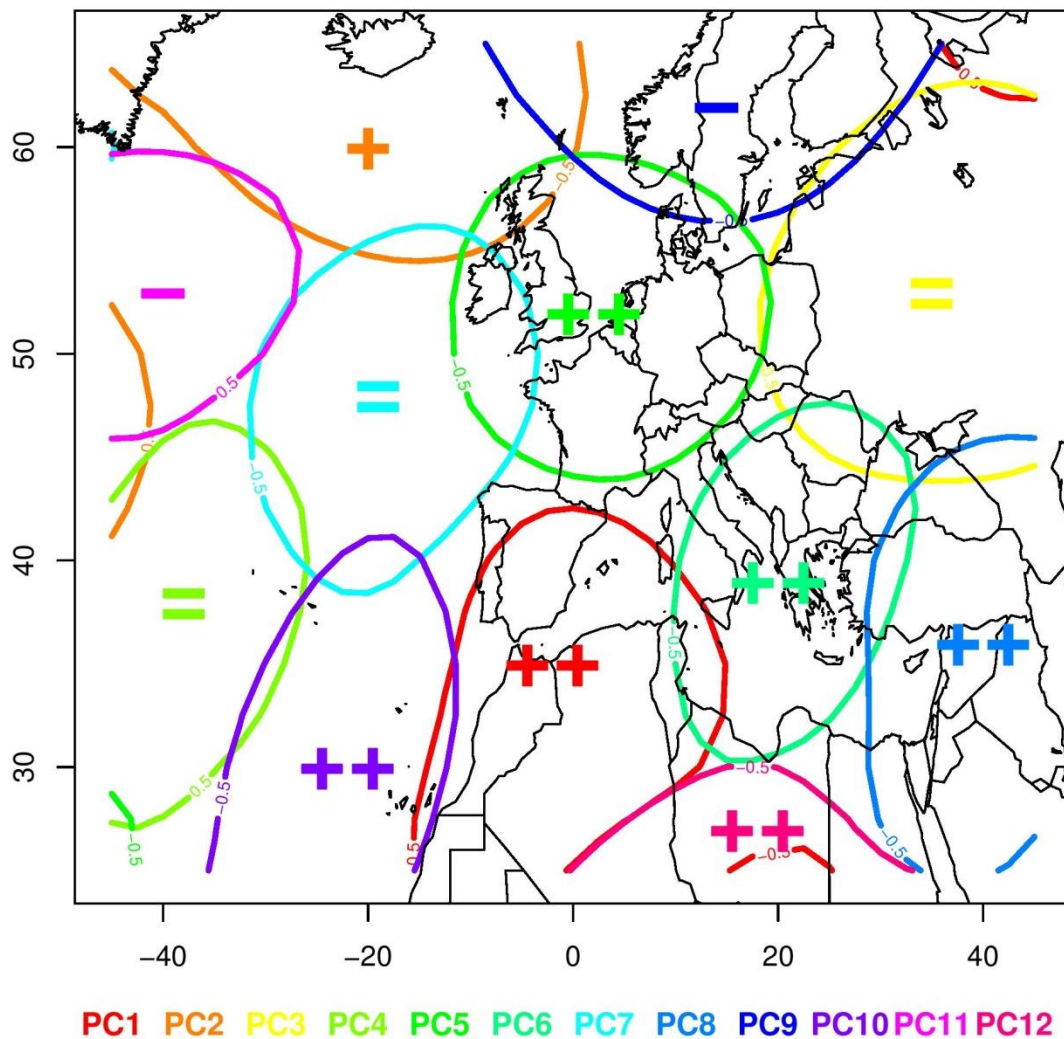


Figura 4.4 Representación de la contribución de cada PC al campo de tendencias de altura geopotencial del bimés de Mayo-Junio para el reanálisis NCEP/NCAR (Figura 1.1(a)).



Respecto al resto de modelos del CMIP5, en la *Tabla II.1* tenemos tres resultados para cada uno. Los dos primeros, también presentes en el reanálisis NCEP/NCAR indican el valor de la tendencia obtenida a partir del ajuste por mínimos cuadrados (**b**) y su correspondiente significancia estadística (**P**). Recordamos que para considerar que un resultado sea estadísticamente significativo tiene que tener una probabilidad de tendencia no nula superior a 0.95. El tercero (%) representa que porcentaje de la tendencia de las observaciones de ese PC han conseguido reproducir los modelos. Este resultado a diferencia de los dos anteriores, se halla presente solamente en aquellos PCs en los que hemos obtenido una tendencia estadísticamente significativa en las observaciones. Esto es debido a que no es relevante conocer cuánto están reproduciendo los modelos de una tendencia que no podemos afirmar con garantía estadística.

De cara a analizar los resultados presentes en esta tabla, se ha decidido resaltar los valores con distintos colores según el tipo de resultado obtenido. En verde se hallan destacados los resultados en que coinciden ambos, observaciones y modelo para el mismo PC, en obtener una tendencia estadísticamente significativa y que además, la tendencia del modelo reproduce entre un 85% y un 115% de la tendencia de las observaciones. Hemos definido este rango de porcentajes como el umbral que un modelo tiene que alcanzar para que se considere que éste está haciendo una buena descripción de las observaciones. Siguiendo con este razonamiento, en amarillo están destacados los resultados que cumplen con la primera premisa, que ambos obtengan una tendencia estadísticamente significativa, pero sin embargo están fuera del rango de porcentajes considerado. Por otra parte, en rojo se hallan destacadas las casillas en que hemos obtenido un resultado contradictorio con las observaciones, esto sucede en los casos en que las observaciones han obtenido una tendencia estadísticamente significativa y los modelos no y viceversa, resultados de los modelos que obtienen tendencias significativas en PCs donde las observaciones no han mostrado tal resultado. Por último, en gris se hallan los resultados que para ambos conjuntos no han obtenido una tendencia en la influencia de ese PC con suficiente significancia estadística.

#### **4.2. PCA: análisis regional**

En el capítulo inicial explicamos que este trabajo estaba motivado por el calentamiento observado en el Mediterráneo Occidental con respecto al observado a escala global y vimos cómo estaba relacionado con las tendencias del H500. En esta sección se analizará que información complementaria puede aportar el PCA a esta situación.

En el capítulo 3 se ha explicado como mediante los *scores* y *loadings* se puede reconstruir el campo original (ecuación (3)), así bien, si en lugar de considerar los *scores* se utilizan sus tendencias temporales se obtendrá el campo de tendencias del H500. Si se compara el mapa de la *Figura 4.5*, donde están representadas las tendencias recreadas a partir de los *scores* y PCs, con el de la *Figura 1(a)*, se observará que ambos mapas concuerdan. Las pequeñas diferencias que pueda haber son debidas a la pérdida de varianza del sistema original al truncar la base de PCs. A continuación se analizará qué PCs son los causantes de esta gran tendencia positiva del H500 sobre el Mediterráneo Occidental.




Figura 4.5 Tendencias recreadas a partir de las tendencias de los *scores* del reanálisis NCEP/NCAR para el bimestre de Mayo-Junio

Si se observan los mapas de los PCs rotados en el Anexo II vemos que por proximidad, localmente los PCs que más deberían influir en estas tendencias son el PC1, PC5 y PC6, pero como ya se ha comentado, depende del comportamiento de sus respectivos *scores*. De cara a realizar el análisis local de las tendencias, seleccionaremos un punto de la malla de nuestro dominio lo más próximo posible a las Islas Baleares. En la malla espacial del reanálisis NCEP/NCAR este punto corresponde a las coordenadas (40°N, 2.5°E).

El cálculo directo de tendencias a partir del H500 en este punto daba como resultado una tendencia de 1.79 gpm/year<sup>4</sup>. Mediante la recreación de tendencias a partir del PCA en el mismo punto, se obtiene una tendencia de 1.67 gpm/year. No se alcanza la misma intensidad debido a la truncación de PCs, aunque aun así se obtiene una intensidad elevada y muy superior al resto de la región (Figura 4.5). Partiendo de este dato, se calculó la contribución de cada PC a esta tendencia; estos resultados se pueden ver en la Figura 4.6. Claramente el principal causante de esta tendencia es el PC1, aportando hasta un 54% de la evolución del H500. Esto se debe a la ubicación geográfica del PC (ocupa la totalidad del Mediterráneo Occidental) y de que sus *scores* presentan la evolución temporal más fuerte, y positiva, respecto al resto de *scores* del reanálisis NCEP/NCAR. La siguiente contribución más importante está originada por el PC5 con un 18%, este PC representa un modo de variabilidad negativo y aunque sus *scores* presenten una tendencia negativa de casi la misma magnitud que el PC1, el hecho de que se encuentre desplazado y no afecte de forma tan directa explica que obtengamos una contribución mucho más baja que el PC1. En un principio, concluimos que basándonos puramente en la ubicación geográfica de los PCs, los que más deberían contribuir a la tendencia del H500 sobre el punto de análisis son el PC1, PC5 y PC6. En el caso de los dos primeros se ha cumplido debido a que sus *scores* mostraban claras tendencias, sin embargo, en el PC6, sus *scores* muestran unas tendencias más débiles que el resto de PCs, causando así que no contribuya tanto a la tendencia total respecto al resto de PCs. Por tanto, alrededor de un 80% de la tendencia del H500 sobre las Islas Baleares, puede ser explicado a partir de los modos de variabilidad de 3 PCs (PC1, PC5 y PC8, el cual representa un 6%).

<sup>4</sup> gpm/year corresponde a metros geopotenciales por año




Figura 4.6 Contribución de cada PC a la tendencia local de 1,67 gpm/year (barras). Contribución total (línea punteada).

## 5. Discusión y conclusiones

### 5.1. Fuentes de error

Como base de este trabajo se han utilizado campos de los modelos del CMIP5 los cuales están obtenidos mensualmente. Esto produce que a la hora de realizar el ajuste de la serie temporal únicamente tengamos 35 valores, provocando que la variabilidad de los datos sea mayor que la tendencia de la serie, obteniendo así una gran cantidad de resultados estadísticamente no significativos.

Una primera solución de este problema hubiese sido considerar un dominio temporal más amplio, aumentando de esta forma el volumen de la serie temporal permitiendo obtener más resultados estadísticamente significativos. Pero como ya se ha comentado, se optó por este dominio ya que el objetivo principal era reproducir los resultados obtenidos por Jansà et al, (2016).

Otra posible solución, *a priori*, sería considerar campos diarios en lugar de mensuales. Esto produciría una serie temporal más extensa (tendríamos más muestreo) pero realmente no se estaría añadiendo información real, sino que estaríamos añadiendo ruido al valor medio del mes, que es el dato que en este trabajo se está considerando, así que esto no resolvería el problema.

## **5.2. Comentarios finales sobre los resultados**

En este trabajo se ha conseguido aplicar los fundamentos teóricos del análisis de Componentes Principales a un campo de altura geopotencial, obteniendo de forma satisfactoria sus principales modos de variabilidad. El posterior análisis de éstos y cómo evoluciona su efecto sobre el campo total ha revelado, no sólo la deficiente simulación de los cambios en H500 simulados por los modelos CMIP5, sino que además han aportado información adicional sobre estas tendencias observadas.

En la Tabla II.1 se ha podido ver que de los 240 resultados que contiene, tan solo se han obtenido 31 casos en que ambos, modelos CMIP5 y observaciones, obtuviesen tendencias estadísticamente significativas; de los cuales solamente 10 resultados indican que los modelos reproducen adecuadamente las observaciones. Por el contrario, hay hasta 95 casos en que los modelos y las observaciones discrepan. La mayoría de estos resultados se encuentran en PCs donde los modelos no han sido capaces de reproducir las tendencias mostradas por las observaciones. El resto, 26, corresponden a PCs donde las observaciones no han mostrado una clara tendencia y sin embargo los modelos sí.

La deficiente simulación de la evolución de unos pocos PCs responsables del notable incremento del geopotencial a 500hPa sobre el Mediterráneo Occidental durante el bimes Mayo-Junio, y de la estivalización asociada de las condiciones cerca de superficie es el resultado más notable de este estudio, que profundiza en los resultados obtenidos por Jansà et al. (2016). Los modelos climáticos teóricamente deberían ser capaces de reproducir los procesos atmosféricos comprendidos en un periodo climático. La OMM (Organización Meteorológica Mundial) define un periodo climático como un intervalo de 30 años. En este trabajo se hace un estudio de 35 años, el cual se encuentra dentro de las escalas temporales en las que un modelo climático debería reproducir buenos resultados. El hecho de que esto no ocurra revela un resultado muy relevante de cara a la confianza sobre el uso de estos modelos.

Referente al estudio de las fuertes tendencias observadas localmente en los campos de altura de geopotencial en los meses de Mayo y Junio para el periodo de 1971 a 2005, hemos conseguido, mediante el PCA, identificar a que modos de variabilidad se debe este incremento y analizar su contribución. Como resultado hemos obtenido que el aumento de la influencia del PC1 (modo de variabilidad positivo del H500 ubicado sobre el Mediterráneo Occidental), y el debilitamiento del PC5 (modo de variabilidad positivo del H500 ubicado sobre el noroeste de Europa) sobre el campo de alturas geopotenciales son los principales causantes del fuerte aumento de éste en la zona de análisis (72% de la tendencia total, 54% y 18% respectivamente). Fuera del marco local, podemos ver como el resto de PCs ubicados en la banda latitudinal del Mediterráneo también indican una fuerte tendencia positiva del H500.



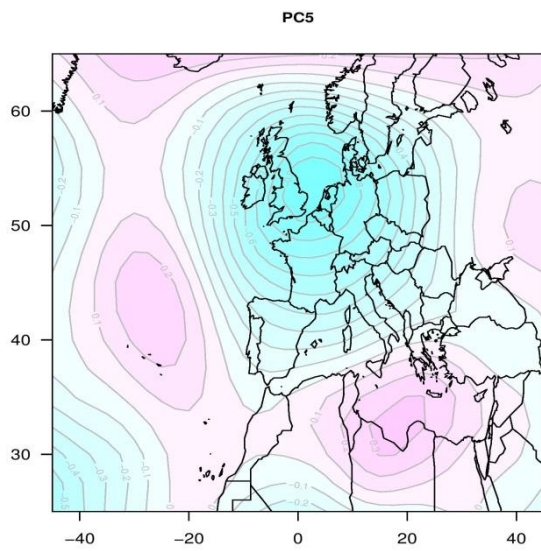
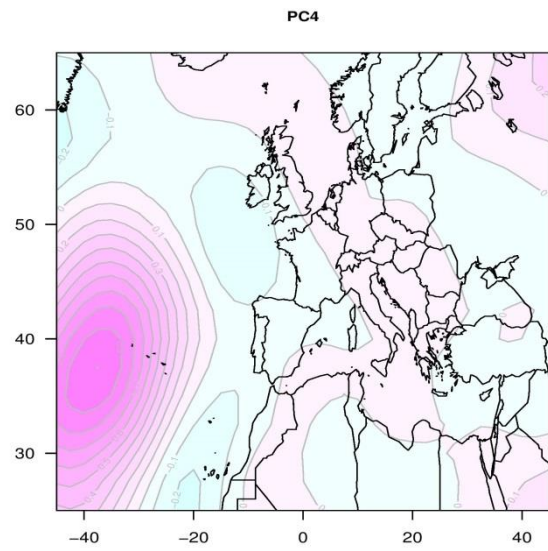
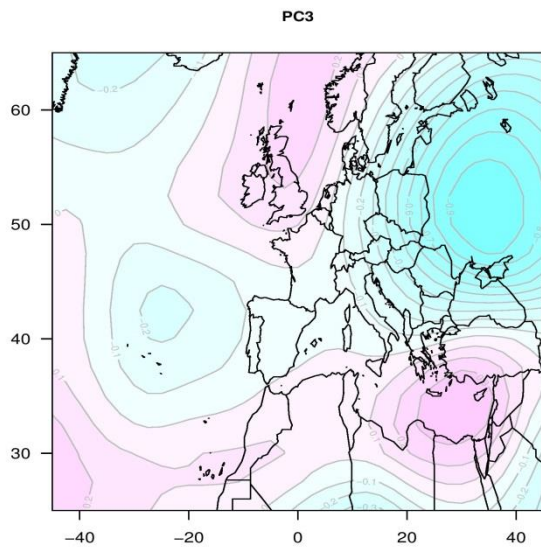
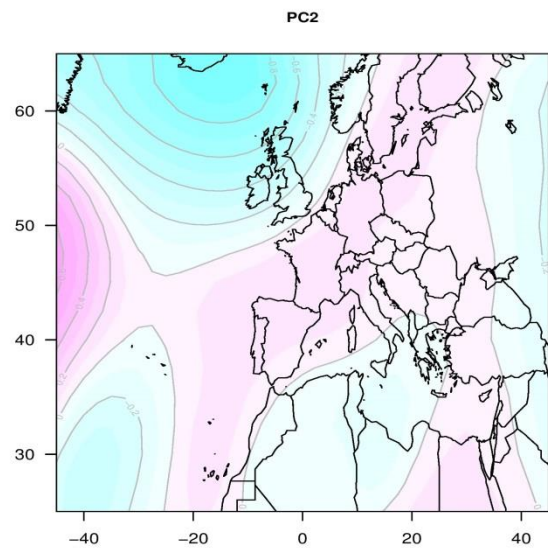
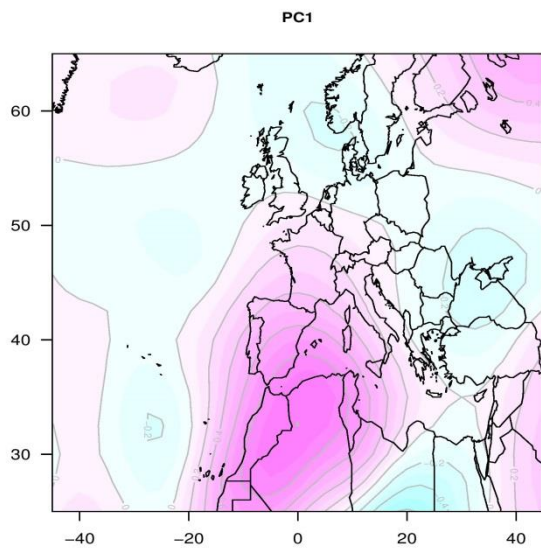
## **5.3. Futuras líneas de trabajo**

En este trabajo quedan cuestiones abiertas que servirían como futuras líneas de trabajo. Un proyecto interesante sería la realización de un análisis de los forzamientos presentes en la atmosfera y averiguar las causas físicas que rigen los modos principales de variabilidad de las observaciones. Con este conocimiento, tal vez se podría realizar un mejor análisis de los resultados aquí obtenidos. Conociendo esto, no solo se entenderían mejor las carencias de los modelos a la hora de reproducir las observaciones sino que además tal vez de forma indirecta, mediante el estudio de estos forzamientos se podría hacer un cálculo predictivo sobre las


tendencias de los PCs. El análisis de las causas físicas, centrándose en argumentos de circulación global y sus forzamientos, podría arrojar luz sobre las deficiencias en los modelos que causan los resultados aquí descritos.

Otra línea sería realizar, como ya se ha comentado, un análisis de los *scores* de los PCs de los modelos. Este análisis, aunque tedioso, tal vez aportaría una información diferente o nueva a la que se obtiene mediante el análisis de sus tendencias.

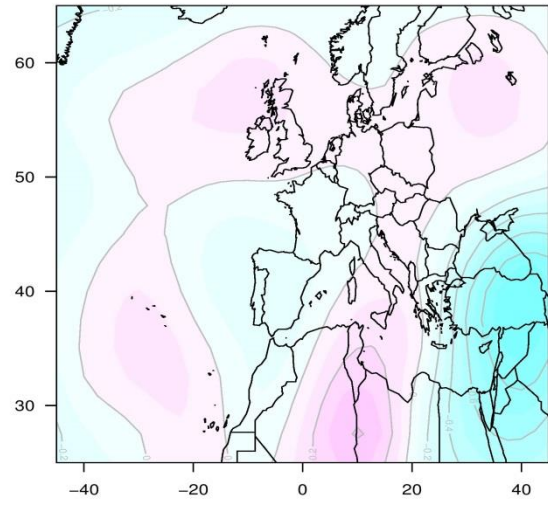
# Anexo I



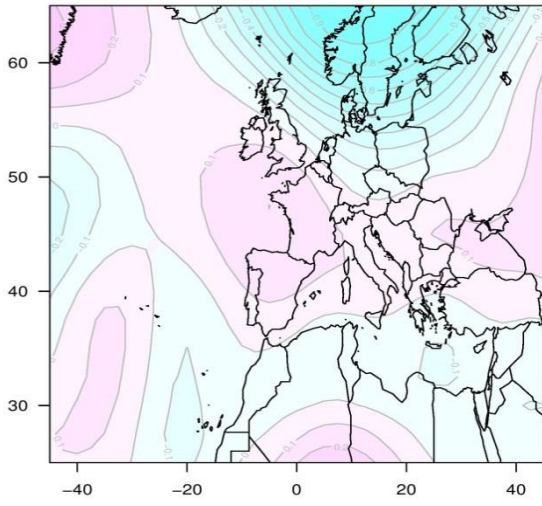
PC7




PC8




PC9




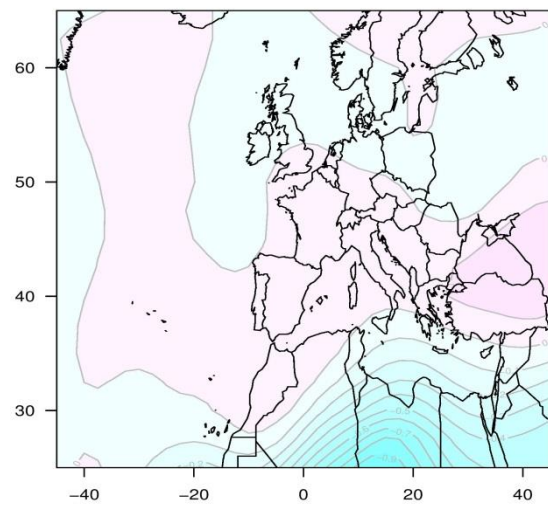
PC10



PC11



PC12



## Anexo II

		PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10	PC11	PC12
NCEP/NCAR	<b>b</b>	0,39	-0,14	0,05	-0,03	-0,35	-0,25	0,01	-0,32	0,21	-0,34	-0,08	-0,17
	<b>P</b>	0,99	0,71	0,30	0,19	0,99	0,98	0,08	0,99	0,91	0,99	0,49	0,92
EC-EARTH_r2i1p1	<b>b</b>	0,30	0,04	-0,11	0,15	0,16	-0,07	-0,06	-0,20	0,18	-0,34	0,04	-0,17
	<b>P</b>	0,99	0,29	0,66	0,82	0,75	0,48	0,36	0,93	0,88	0,99	0,32	0,90
	<b>%</b>	76%	--	--	--	-45%	29%	--	61%	--	99%	--	--
EC-EARTH_r9i1p1	<b>b</b>	0,18	0,08	0,09	0,41	-0,20	-0,10	-0,25	-0,04	0,05	-0,24	-0,04	-0,21
	<b>P</b>	0,92	0,52	0,48	0,99	0,90	0,61	0,97	0,31	0,36	0,99	0,27	0,95
	<b>%</b>	47%	--	--	--	56%	42%	--	13%	--	70%	--	--
HadCM3_r1i1p1	<b>b</b>	0,10	0,09	-0,16	0,28	-0,11	-0,01	-0,14	-0,02	-0,08	-0,24	0,04	-0,06
	<b>P</b>	0,63	0,51	0,79	0,99	0,60	0,05	0,73	0,18	0,54	0,99	0,30	0,46
	<b>%</b>	26%	--	--	--	30%	3%	--	8%	--	70%	--	--
HadCM3_r2i1p1	<b>b</b>	0,31	-0,06	0,05	0,06	-0,11	-0,15	-0,12	-0,27	0,06	-0,29	-0,12	-0,15
	<b>P</b>	0,98	0,41	0,28	0,43	0,65	0,82	0,63	0,99	0,49	0,99	0,76	0,85
	<b>%</b>	80%	--	--	--	31%	60%	--	83%	--	85%	--	--
HadCM3_r3i1p1	<b>b</b>	0,32	-0,01	0,06	0,27	0,08	0,00	-0,10	-0,13	-0,10	-0,37	0,11	-0,38
	<b>P</b>	0,99	0,10	0,39	0,99	0,51	0,01	0,55	0,80	0,57	0,99	0,66	0,99
	<b>%</b>	83%	--	--	--	-23%	-1%	--	42%	--	109%	--	--
HadCM3_r4i1p1	<b>b</b>	0,04	-0,01	0,20	0,23	-0,05	0,15	-0,05	-0,08	-0,09	-0,19	-0,13	-0,22
	<b>P</b>	0,27	0,04	0,89	0,96	0,29	0,83	0,31	0,59	0,58	0,96	0,72	0,95
	<b>%</b>	10%	--	--	--	14%	-59%	--	25%	--	55%	--	--
HadCM3_r5i1p1	<b>b</b>	0,32	-0,29	0,10	-0,02	-0,20	0,04	-0,21	-0,14	0,03	-0,27	0,02	-0,28
	<b>P</b>	0,99	0,99	0,56	0,12	0,88	0,30	0,89	0,81	0,22	0,99	0,15	0,99
	<b>%</b>	82%	--	--	--	55%	-17%	--	44%	--	78%	--	--
HadCM3_r6i1p1	<b>b</b>	0,24	-0,16	-0,30	0,14	0,08	-0,10	0,07	-0,24	-0,11	-0,06	0,28	-0,32
	<b>P</b>	0,94	0,85	0,99	0,82	0,48	0,59	0,44	0,98	0,63	0,40	0,99	0,99
	<b>%</b>	61%	--	--	--	-22%	39%	--	75%	--	16%	--	--
HadCM3_r7i1p1	<b>b</b>	0,26	-0,11	-0,10	0,08	-0,16	-0,16	-0,01	-0,09	0,01	-0,12	0,12	-0,23
	<b>P</b>	0,98	0,70	0,61	0,61	0,81	0,82	0,03	0,58	0,08	0,69	0,73	0,98
	<b>%</b>	68%	--	--	--	45%	63%	--	27%	--	34%	--	--
HadCM3_r8i1p1	<b>b</b>	0,06	0,00	-0,09	0,15	-0,18	-0,03	0,02	-0,07	-0,26	-0,16	-0,09	-0,11
	<b>P</b>	0,40	0,01	0,52	0,83	0,86	0,20	0,10	0,52	0,98	0,87	0,56	0,74
	<b>%</b>	16%	--	--	--	52%	12%	--	22%	--	46%	--	--
HadCM3_r9i1p1	<b>b</b>	0,00	-0,08	0,02	0,22	0,07	0,04	-0,06	-0,10	-0,06	-0,15	0,14	-0,29
	<b>P</b>	0,02	0,58	0,14	0,99	0,50	0,22	0,33	0,69	0,37	0,86	0,75	0,99
	<b>%</b>	1%	--	--	--	-20%	-15%	--	30%	--	43%	--	--
HadCM3_r10i1p1	<b>b</b>	0,38	0,06	-0,23	0,06	-0,06	-0,23	0,05	-0,28	0,00	-0,24	-0,06	-0,12
	<b>P</b>	0,99	0,41	0,95	0,37	0,37	0,95	0,34	0,99	0,01	0,99	0,40	0,76
	<b>%</b>	97%	--	--	--	16%	93%	--	86%	--	70%	--	--
HadGEM2-ES_r2i1p1	<b>b</b>	0,30	-0,19	-0,06	-0,02	-0,11	-0,20	0,08	-0,20	0,00	-0,21	0,00	-0,19
	<b>P</b>	0,99	0,90	0,33	0,14	0,63	0,96	0,52	0,97	0,01	0,93	0,03	0,94
	<b>%</b>	77%	--	--	--	31%	81%	--	64%	--	62%	--	--
HadGEM2-ES_r3i1p1	<b>b</b>	0,24	-0,17	-0,20	-0,18	-0,22	-0,08	-0,20	-0,34	0,02	-0,09	0,12	-0,12
	<b>P</b>	0,96	0,82	0,90	0,91	0,92	0,51	0,91	0,99	0,12	0,63	0,73	0,75
	<b>%</b>	61%	--	--	--	62%	32%	--	105%	--	27%	--	--
HadGEM2-ES_r5i1p1	<b>b</b>	0,07	0,09	-0,24	0,44	-0,28	-0,30	-0,12	-0,30	-0,29	-0,24	0,00	-0,30
	<b>P</b>	0,46	0,57	0,97	0,99	0,99	0,99	0,70	0,99	0,98	0,97	0,01	0,99
	<b>%</b>	18%	--	--	--	80%	119%	--	94%	--	69%	--	--
MRI-CGCM3_r1i1p1	<b>b</b>	0,08	0,10	0,05	0,11	-0,23	-0,11	-0,24	-0,17	0,15	-0,13	-0,07	-0,15
	<b>P</b>	0,52	0,59	0,30	0,72	0,95	0,60	0,95	0,94	0,80	0,78	0,51	0,90
	<b>%</b>	21%	--	--	--	66%	43%	--	54%	--	37%	--	--
MRI-CGCM3_r2i1p1	<b>b</b>	-0,07	0,04	-0,19	0,12	-0,03	-0,19	-0,29	-0,28	0,01	-0,04	0,12	-0,28
	<b>P</b>	0,43	0,31	0,84	0,73	0,19	0,92	0,99	0,99	0,07	0,30	0,76	0,99
	<b>%</b>	-19%	--	--	--	9%	76%	--	89%	--	12%	--	--
MRI-CGCM3_r3i1p1	<b>b</b>	-0,06	-0,03	0,06	0,09	-0,14	0,12	-0,19	-0,14	-0,13	-0,02	0,06	-0,30
	<b>P</b>	0,36	0,18	0,40	0,58	0,77	0,71	0,87	0,83	0,66	0,13	0,49	0,99
	<b>%</b>	-15%	--	--	--	40%	-49%	--	43%	--	6%	--	--
MRI-CGCM3_r4i1p2	<b>b</b>	0,09	0,09	-0,16	0,20	-0,11	-0,04	0,17	-0,02	-0,15	-0,30	-0,10	0,00
	<b>P</b>	0,52	0,52	0,79	0,93	0,66	0,28	0,88	0,17	0,78	0,99	0,68	0,01
	<b>%</b>	23%	--	--	--	32%	16%	--	7%	--	86%	--	--
MRI-CGCM3_r5i1p2	<b>b</b>	0,06	-0,08	0,07	-0,04	0,00	0,00	0,00	-0,21	0,07	-0,16	-0,01	-0,17
	<b>P</b>	0,35	0,51	0,43	0,30	0,00	0,01	0,02	0,97	0,41	0,85	0,05	0,91
	<b>%</b>	14%	--	--	--	0%	0%	--	66%	--	47%	--	--

Tabla II.1 Resultados de los ajustes lineales por mínimos cuadrados de las series temporales de los scores para cada PC de cada modelo (**b**), significancia estadística (**P**), porcentaje reproducido de la tendencia de las observaciones (**%**). Resultados significativos y que solo difieren en un 15% (verde), resultados significativos pero que difieren en más de un 15% (amarillo), resultados en que modelos u observaciones han obtenido resultados significativos y el otro no (rojo), resultados en que ambos, modelos y observaciones han obtenido resultados no significativos (gris).



## Referencias

- Barry RG, Chorley RJ. 2010. *Atmosphere, Weather and Climate*, 9th edn. Routledge, Taylor & Francis Group: London and New York, NY, 516 pp.
- Birner T, Davis SM, Seidel DJ. 2014. The changing width of Earth's tropical belt. *Phys. Today* **67**(12): 38, doi: 10.1063/PT.3.2620.
- Hu Y, Fu Q. 2007. Observed poleward expansion of the Hadley circulations since 1979. *Atmos. Chem. Phys.* **7**: 5229–5236.
- IPCC. 2013. Climate change 2013: the physical science basis. In *Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, Stocker TF, Qin D, Plattner G-K, Tignor M, Allen SK, Boschung J, Nauels A, Xia Y, Bex V, Midgley PM (eds). Cambridge University Press, 1535 pp.: Cambridge, UK and New York, NY, doi: 10.1017/CBO9781107415324.
- Jansà A. 2012. Primavera i canvi climàtic (Climatic change and spring; in Catalan). *Territoris* (Universitat de les Illes Balears) **8**: 129–142, ISSN: 1139-2169.
- Jansà A, Homar V, Romero R, Alonso S, Guijarro JA, Ramis R. 2016. Extension of summer climatic conditions into spring in the Western Mediterranean sea. *Int. J. Climatol*, DOI: 10.1002/joc.4824.
- Jolliffe IT. 2002, *Principal Component Analysis*, Springer series in statistics, ISBN: 0-387-95442-2
- Taylor, K.E., R.J. Stouffer, G.A. Meehl 2012: An Overview of CMIP5 and the experiment design.” *Bull. Amer. Meteor. Soc.*, **93**, 485-498, doi:10.1175/BAMS-D-11-00094.1.
- Trigo R, Xoplaki E, Zorita E, Luterbacher J, Krichak SO, Alpert P, Jacobeit J, Saenz J, Fernandez J, Gonzalez-Rouco F, Garcia-Herrera R, Rodo X, Brunetti M, Nanni T, Maugeri M, Türkeş M, Gimeno L, Ribera P, Brunet M, Trigo IF, Crepon M, Mariotti A. 2006. Chapter 3: Relations between variability in the Mediterranean región and mid-latitude variability. In *Mediterranean Climate Variability*, Lionello P, Malanotte-Rizzoli P, Boscolo R (eds). Elsevier: Amsterdam, 179–226.
- Wilks DS. 2006, *Statistical Methods in the Atmospheric Sciences*, International geophysics series, ISBN 13: 978-0-12-751966-1.